2X-06

深層距離学習を用いた加速度センサデータからのコンテキスト推定

桂田　連†　　長谷川　達人†

福井大学大学院工学研究科†

1.はじめに

スマートフォンの普及に伴い，端末に搭載されているモーションセンサを用いて様々なコンテキストを推定するコンテキストアウェアネス研究が盛んに行われている．本分野の研究が進み、多様な状況を機械が把握できるようになれば，提供できるコンシューマサービスの幅も増え，生活も豊かになる．我々は，以前より歩行時に着目した路面の積雪量[1]や，歩行中の端末の所持位置[2]という，歩行時のコンテキスト推定課題の実現可能性について議論を深めてきた．しかし，我々が扱ってきたマイナーコンテキストな分野では，実現に向けたさらなる精度向上が必要である．

一方，深層距離学習（DML）と呼ばれる手法がある．DML とは，空間上のデータ分布に着目し，特定データについて，類似データとの距離を近く，非類似データとの距離を遠くに分布するような特徴表現を獲得する学習手法である．この手法を適用することで，新たに分類を容易にする特徴量獲得が期待でき，精度向上に繋がると考えられる．距離学習手法には，入力データを 2 つ組にする Siamese Network[3]や，Anker（基準データ），Positive（類似データ），Negative（非類似データ）の 3 種類の入力を用いた Triplet Network[4]等がある．本研究では，より良い性能を示している Triplet Network を用いる．

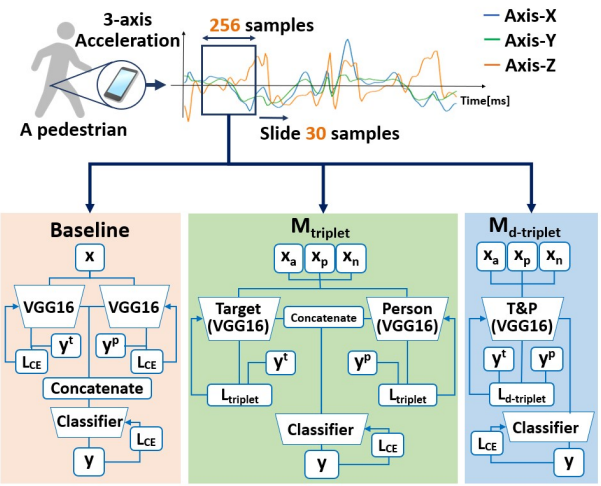

図１．提案手法概要とモデルの各構成

Context estimation from accelerometer data using deep metric learning
†Ren Katsurada, Tatsuhito Hasegawa
Graduate school of University of Fukui

コンテキストアウェアネスの分野においては，DML が応用されている事例は殆ど見られない．そこで本研究では，我々がこれまで行ってきた所持位置推定や積雪量推定に DML を適用し，推定精度への影響を考察する．本研究の立ち位置は，上記 2 点の課題に対して，ターゲットラベルと人物ラベルを併用した，2 種類の DML の導入手法を提案し，推定精度への影響を明らかにすることである．

2.提案手法

提案する手法の概要を図１に示す．提案手法は図１に示す $M_{triplet}$ と $M_{d\text{-}triplet}$ の２種類である．全モデルに共通する事項として，入力データは加速度センサデータ 256 サンプルを 1 フレームとし，これを 30 サンプルずつスライドさせてモデルに入力する．

比較対象とする Baseline モデルでは，センサデータからの特徴抽出を VGG16 モデルで行い，一般的な Cross Entropy 誤差を損失関数としてモデルを訓練する．x は入力データ，y は出力である．y^t は Target（積雪量や所持位置）における正解ラベルであり，y^p は Person（端末所持者）の正解ラベルである．なお，DML と条件を統一するため，人物ラベルである Person も併用したマルチラベル学習モデルとなっている．ここで，2 つの VGG16 間で重みは共有していない．

提案手法では特徴抽出部に DML を用いる．x_a, x_p, x_n は Triplet Loss における Anker, Positive, Negative データである．Model1 では Target と Person の 2 ラベルに対して，それぞれ独立したモデルで，以下の式(1)に示す Triplet Loss（$L_{triplet}$）を損失関数として訓練する．

$$L_{triplet} = \max(d_p - d_n + m, 0) \quad \cdot\cdot\cdot (1)$$

d_p, d_n はそれぞれ同一グループ内のサンプルとの距離，相違グループのサンプルとの距離である．距離はユークリッド距離で算出する．m はマージンであり，本研究では 1.3 とする．なお，特徴抽出モデルには Baseline に合わせて VGG16 を用

Copyright ©2020 Information Processing Society of Japan.
All Rights Reserved.

表１．対象課題のデータ詳細の差異

	入力センサ	利用端末	sampling 周波数	被験者数	データ数
積雪量推定	加速度	iPhone7 等	100Hz	8 名	6612 件
所持位置推定	加速度	Nexus5 等	50Hz	12 名	16153 件

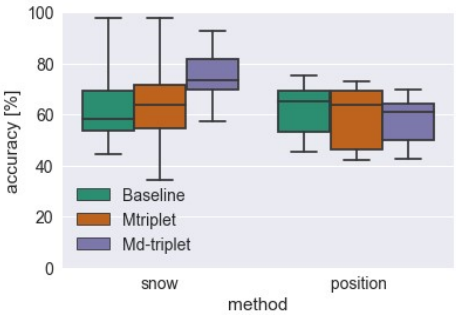

図２．各種推定の手法別評価結果

いており，出力層のみユニット数 80 に変更している．また，後の分類器(Classifier)には VGG16 の畳込み層 13 層目の出力を利用する．Target, Person 双方の特徴抽出モデルの出力を結合し，特徴量 160 次元を分類器へ入力する．分類器部は全結合層のみで構成し，ユニット数は 500, 100, x の 3 層(x は Target に応じて可変)とする．

また，DML の適用方法を $M_{triplet}$ から変更した $M_{d\text{-}triplet}$ についても提案する．損失関数 $L_{d\text{-}triplet}$ を利用し，Target, Person 両方に有用な特徴を同時に獲得するようにしている．$L_{d\text{-}triplet}$ を以下の式(2)に示す．

$$L_{d-triplet} = \left(L^{t}_{triplet} + L^{p}_{triplet}\right)/2 \qquad \cdots (2)$$

$L^{t}_{triplet}$ は Target ラベルに基づいて算出する Triplet Loss であり，$L^{p}_{triplet}$ は Person ラベルに基づくものである．

3.評価実験

3.1. データセットと評価手法

利用するデータセットと，その差異を表 1 に示す．各々先行研究で収集したデータセットを利用する．スマートフォンを用いて端末を各所持位置に格納した後，対象道路を 1 分間程度歩行してもらった．積雪量の場合は端末格納位置をズボン右ポケットと指定している．また，評価手法としては被験者単位でテストデータを交差検証する LOSO-CV を利用する．利用ラベルは Target と Person を双方用い，L_{CE} を用いた Baseline，$L_{triplet}$ を用いた $M_{triplet}$，$L_{d\text{-}triplet}$ を用いた $M_{d\text{-}triplet}$ で比較検証する．

3.2. 評価実験結果

各種推定の実験結果を図 2 に示す．これは，被験者毎の精度の分布を箱ひげ図で示したものである．図 2 中の snow は積雪量推定，position は所持位置推定の結果である．積雪量推定について，$L_{d\text{-}triplet}$ を用いることでより多くの被験者のデータにおいて精度向上を達成している．低精度者の精度向上が多くみられ，中央値としては 73.6%と，Baseline の 58.5%と比べ約 15%の精度向上を達成した．$L_{triplet}$ の様に複数ラベルを個別に訓練した場合でも精度向上は見られるが，両方を同時に訓練する方が積雪量推定にはより効果がある結果となった．

図 2 より，所持位置推定の場合はどの手法を用いても精度は大きくは変化しなかった．積雪量との相違点は，サンプル数やラベルの種類が多い点である．ラベル間のデータの特徴の差異が比較的小さいため，分類難易度が高かったと考えられる．本研究における所持位置推定のように，分類難易度が高い課題に対しては，提案手法を用いても有効には働いていない．別途，有効な手法を考える必要がある．

4.おわりに

路面積雪量推定と所持位置推定という 2 種類の課題に対し，DML を導入した機械学習手法を提案し，評価した．路面積雪量の推定というドメインにおいては提案手法が有効に働き，推定精度約 15%の向上を達成した．しかし，比較的データ数や分類対象が多い所持位置推定では，一般的な CNN モデルと同程度の推定精度であった．今後，有効に働く条件を詳細に明らかにし，さらなる改善手法を模索していきたい．

謝辞

本研究の一部はスズキ財団の科学技術研究助成によるものである．ここに謝意を表す．

参考文献

[1] Katsurada, Ren, et al. "Estimation of Road Snow Accumulation Using Smartphones to Create Snow Cover Maps for Pedestrians." TENCON 2018-2018 IEEE Region 10 Conference. IEEE, pp.0599-0604, 2018.

[2] 桂田連, 他. "端末所持位置推定における転移学習の有効性検証." マルチメディア,分散協調とモバイルシンポジウム 2019 論文集. pp.320-327, 2019.

[3] Hadsell, Raia, et al. "Dimensionality reduction by learning an invariant mapping." 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06) Vol. 2. IEEE, pp.1735-1742, 2006.

[4] Hoffer, Elad, et al. "Deep metric learning using triplet network." International Workshop on Similarity-Based Pattern Recognition. Springer, Cham, pp.84-92, 2015.

Copyright ©2020 Information Processing Society of Japan.
All Rights Reserved.